doi:10.6041/j.issn.1000-1298.2026.23.024

基于无人机图像双模态特征融合的小麦氮素含量估算方法

冀汶莉　凌雨欣　王佳豪
(西安科技大学通信与信息工程学院, 西安 710054)

摘要: 氮素(N)是小麦生长过程中最重要的营养元素之一,根据土壤供氮能力和小麦生长需求进行精准施肥,不仅能提高小麦产量和品质,还能减少氮肥过量对环境造成的污染。本文以陕西省中部冬小麦叶片氮素含量为研究对象,提出一种无人机图像双模态特征融合的小麦氮素含量估算方法。首先,使用无人机获取大面积小麦冠层图像,同步利用自主研发的便携式土壤多参数采集仪快速采集对应位置麦田土壤的温度、含水率、氮含量、磷含量、钾含量和 pH 值 6 种环境参数,并通过 4G 网络传输至自主研发的智慧农田管理系统进行存储。然后,基于小麦冠层图像计算红蓝通道比值(R/B)、绿叶指数(GLI)等 20 种图像特征,利用相关熵分析法将 20 种图像特征、采集的 6 种土壤环境参数分别与实验室测定的小麦叶片氮素含量数据计算相关性,选择出相关熵系数大于 0.7 的特征作为估算模型的候选输入特征。接着,将候选特征送入 BP 神经网络与小麦叶片氮素含量真实值进行回归分析,筛选出与氮素含量强相关的特征。最后,建立了双模态特征融合小麦氮素含量估算模型,对直接输入的小麦冠层图像采用改进 VGG16 卷积神经网络进行深度特征提取,同时将筛选后小麦图像特征和土壤环境参数送入深度信念网络(Deep belief network,DBN)学习与小麦氮素含量的非线性关系,将 2 种不同输出的特征通过 BP 神经网络实现特征融合,输出估算的小麦氮素含量值。试验结果表明,本文所建立的双模态特征融合小麦氮素含量估算模型的决定系数(Coefficient of determination,R^2)为 0.927,均方误差(Mean square error,MSE)为 0.312 g/kg,平均绝对误差(Mean absolute error,MAE)为 0.363 g/kg。该研究可为小麦生长营养监测提供一种可行的方法,为农作物田间管理和精准施肥提供科学指导和技术支持。

关键词: 小麦叶片; 氮素含量估算; 双模态; 无人机图像; 深度信念网络
中图分类号: S127　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)23-0254-12　　**OSID**:

Method for Estimating Wheat Nitrogen Content Using Dual-modal Feature Fusion of UAV Images

Ji Wenli　Ling Yuxin　Wang Jiahao
(*College of Communication and Information Engineering*, *Xi'an University of Science and Technology*, *Xi'an* 710054, *China*)

Abstract: Nitrogen (N) is one of the most essential nutrients for wheat growth. Precision fertilization based on soil nitrogen supply capacity and crop demand not only improves yield and quality but also reduces environmental pollution caused by excessive nitrogen application. The leaf nitrogen content of winter wheat in central Shaanxi Province was investigated, and a dual-modal feature fusion method based on unmanned aerial vehicle (UAV) imagery was proposed for nitrogen content estimation. Large-scale wheat canopy images were acquired using UAVs, while six soil properties—temperature, water content, nitrogen, phosphorus, potassium, and pH were simultaneously collected at corresponding field plots with a self-developed portable soil multi-parameter acquisition device and transmitted via 4G to a self-developed smart farmland management system for storage. Subsequently, totally 20 image features such as the red-blue ratio (R/B) and the green leaf index (GLI) were calculated from canopy images. Correlation entropy analysis was applied to assess the relationships between these 20 image features, the six soil parameters, and laboratory-measured leaf nitrogen content, and features with a correlation coefficient greater than 0.7 were selected as candidate input variables for the estimation model. The selected features were then subjected to regression analysis with a back-propagation (BP) neural network

收稿日期: 2025-09-02　修回日期: 2025-10-23
基金项目: 海南省自然科学基金项目(622RC674)和西安市科技局农业科技创新工程项目(20193054YF042NS042)
作者简介: 冀汶莉(1973—),女,副教授,博士,主要从事深度学习在农业和工业领域应用研究,E-mail: jiwenli@xust.edu.cn

to further identify those strongly associated with nitrogen content. Finally, a dual-modal feature fusion model was established: deep features were extracted directly from UAV canopy images by using an improved VGG16 convolutional neural network, while the screened image features and soil parameters were learned with a deep belief network (DBN) to capture their nonlinear relationships with leaf nitrogen content. The outputs of the two branches were fused through a BP neural network to generate the estimated nitrogen values. Experimental results demonstrated that the proposed model achieved a coefficient of determination (R^2) of 0.927, a mean square error (MSE) of 0.312 g/kg, and a mean absolute error (MAE) of 0.363 g/kg. The research result can provide a feasible approach for monitoring wheat nutritional status and offer scientific and technical support for field management and precision fertilization.

Key words: wheat leaf; nitrogen content estimation; dual-modal; UAV images; deep belief network

0　引言

小麦作为主要粮食作物,其叶片氮素含量直接影响植株生长状态及最终产量,因此对其进行准确估算具有重要意义。传统作物氮素含量估算依赖人工破坏取样,尽管精度较高,但操作繁琐、耗时费力,远不能满足作物大面积、精准化管理需求。无人机技术发展迅速,因其体积小、灵活性高以及成本相对低廉的特点而被逐步应用于农业监测领域。采用无人机搭载高光谱或多光谱相机开展作物氮素含量估算已取得一定成果,但由于光谱波段间存在高度相关性,易造成大量数据冗余[1]且高光谱或多光谱无人机设备价格高昂,限制了其大规模推广。

利用无人机搭载高清数码相机对田间作物长势信息如株高、冠幅、氮素含量、叶绿素含量、挂果量等实时监测和估算逐渐成为研究热点[2-3]。近年来,国内外学者利用无人机搭载高清相机采用机器学习方法进行作物氮素含量估算,并取得了一定研究进展[4-5]。传统机器学习方法结合无人机高清图像进行作物氮素含量估算虽取得一定成果,但大多仍是从图像中人工提取的植被指数、颜色及纹理等特征入手,忽略了图像中的深层语义特征,模型精度仍有很大的提升空间。近年来,深度学习方法,尤其是卷积神经网络(Convolutional neural network, CNN),凭借其强大的自动特征提取能力,已开始应用于作物氮素含量估算等场景,并显示出更优的性能,显著提高氮素含量估算的准确率[6-7]。

尽管利用 RGB 图像结合机器学习或深度学习方法在作物氮素含量估算中已取得诸多进展。但生物学领域研究表明,作物对氮素的吸收能力与土壤环境参数存在密切相关[8]。例如,Djaman 等[9]通过灌溉梯度试验发现,当农田灌水量在 0 ~ 180 mm 范围内时,作物氮素吸收量随灌水量的增加而增加。张宗祥等[10]通过在玉米田设置不同土壤 pH 值的梯度试验,发现土壤呈酸性会抑制玉米对氮素的吸收。土壤环境参数是反映土壤养分状况和理化属性的关键指标,包括土壤氮磷钾含量、pH 值、温度、含水率以及有机质含量等,能够综合表征土壤肥力水平及其对作物生长的潜在影响。然而,目前生物学研究多集中在单一土壤环境参数与氮素吸收的机理分析,而将上述关键指标直接应用于作物氮素含量估算的研究仍相对较少。

无人机获取的 RGB 图像反映了作物生长状况,地面物联网设备采集的土壤环境参数反映了作物当前土壤的种植环境,二者共同构成小麦氮素估算具有时空特性的双模态数据源。为充分挖掘不同模态的高阶特征并实现特征融合,本文引入多模态学习范式建立小麦叶片氮素含量估算模型。多模态是指在深度学习中通过融合多种模态的数据(如图像、文本和语音信息等)进行特征学习[11]。在作物氮素含量估算领域,多模态学习方法正在被学者关注和研究应用[12-13]。然而现有研究中少有将实时多点土壤环境参数和无人机 RGB 图像作为独立特征引入作物氮素含量估算模型。同时,虽然已有研究取得了一定成果,但其估算精度仍有较大提升空间。

为此,本文引入双模态思想,拟构建基于深度学习方法的冬小麦氮素含量估算模型。选择陕西省中部临潼区小麦主产区为研究区域,采用无人机搭载高清相机获取冬小麦灌浆期和起身期的冠层 RGB 图像,并通过自主研发的土壤参数采集仪同步获取麦田土壤氮磷钾含量、温度、含水率以及 pH 值等土壤环境数据。结合实验室实测的小麦叶片氮素含量数据,对模型进行训练与验证。以期为研究区以及邻近周边地区冬小麦氮素含量估算提供理论支撑。

1　材料与方法

1.1　试验区概况与试验设计

无人机和地面土壤环境参数采集区位于陕西省西安市临潼区西安科技大学所在的乡村振兴研究院的合作农业区麦田(北纬 34°19′、东经 109°16′)。

该区域海拔约 1 100 m,属于温带季风气候,年均气温为 13.5℃,年均降水量为 591.8 mm。主要种植作物为冬小麦,9 月播种,次年 4—6 月收获。

试验区分为 2 个数据采集区,采集区 1 东西向长度为 70 m,南北向长度为 20 m,面积约为 1 400 m^2,航向由西向东,采集小麦灌浆期的试验数据。采集区 2 东西向长度为 90 m,南北向长度为 30 m,面积约为 2 700 m^2,航向由西向东,采集小麦起身期的试验数据。采集区 1 划分为 100 个采样地块,采集区 2 划分为 200 个采集地块。每个地块尺寸为 3 m × 3 m,横向间隔 1 m,纵向间隔 2 m。数据采集区域如图 1 所示。

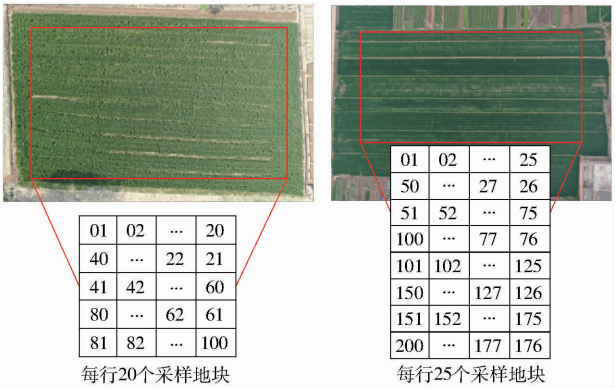

图 1 数据采集区域规划图

Fig. 1 Map of data collection area planning

1.2 数据采集

1.2.1 无人机 RGB 图像及土壤环境参数获取

已有研究表明,小麦在起身期和灌浆期对氮素的需求量达到高峰,叶片的生理特征较为明显,获取的数据更具代表性[14-15]。陕西冬小麦起身期出现在 3 月下旬末,灌浆期出现在 4 月下旬前期。因此本研究中无人机 RGB 影像和地面数据采集时间选择在 2022 年 3 月和 5 月,分别对应冬小麦冠层叶片颜色变化较为明显的起身期与灌浆期。

无人机采用大疆 Mavic 2 Pro,搭载哈苏 Hasselblad L1D-20c 型高清相机。数据采集选择在太阳高度角相对稳定的 12:00 至 14:00 内进行,以减少光照变化对图像质量的影响。拍摄时相机光圈固定为 f/5.6,快门速度初始设置为 1/500 s,并可根据实际光照强度适当微调,ISO 固定为 100,关闭自动曝光功能。规划飞行航线,飞行高度保持在 5 m,并保证 80% 的航向重叠和 60% 的旁向重叠。相机有效像素为 2.0×10^7,最高分辨率为 5 472 像素 × 3 648 像素,获取的数据为包含红、绿、蓝三波段的 JPEG 格式图像。共采集小麦灌浆期和起身期图像 300 幅。采集的无人机图像经过 Agisoft PhotoScan 处理,进行正射校正和几何畸变矫正,并结合地面控制点和 GPS 信息生成数字正射影像,确保影像像元与实地样方精确对应。

无人机进行麦田图像采集的同时,在对应采样地块区域内使用自主研发的便携式土壤多参数采集仪[16]采集土壤环境数据。每个采样地块设置 3 个数据采集节点,将土壤温湿度、pH 值、氮磷钾传感器探针插入距地表 6 cm 深的土壤中,采集土壤环境数据。取各节点采样数据的均值作为该采样地块的土壤环境数据值。自主研发的便携式土壤多参数采集仪实物如图 2 所示,采集仪由移动电源供电[17]。共采集灌浆期和起身期土壤温湿度,氮、磷、钾含量和 pH 值数据 300 组。



(a) 采集节点实物图 (b) 网关节点实物图

图 2 便携式土壤多参数采集仪

Fig. 2 Portable soil multi-parameter data logger

1.2.2 小麦叶片氮素含量测定

为准确标定采样地块小麦叶片氮素含量值,在进行无人机和土壤环境参数采集的同时,在每个采样地块中心布设半径 1.5 m 的取样圆,并在圆心及其上下左右边界各采集 1 株小麦(共 5 株),样本采集方式如图 3 所示。将采集的混合样本编号送至西北农林科技大学作物养分含量检测实验室,通过化学实验方法获得小麦叶片氮素含量的准确值。具体操作为:首先摘除小麦根系,将茎叶分离,将小麦叶片置于 105℃烘箱中杀青 30 min,接着在 80℃下烘干至质量恒定,研磨粉碎后通过凯氏定氮法测定其叶片氮素含量,文中所述测得的氮素含量指干燥研磨后样本的氮质量比(g/kg)。

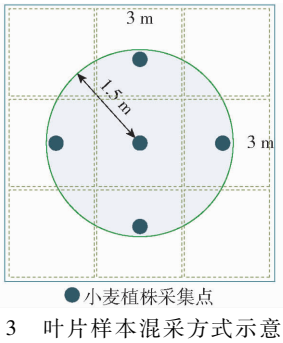

图 3 叶片样本混采方式示意图

Fig. 3 Schematic of mixed sampling method for leaf samples

1.2.3 无人机 RGB 图像预处理

无人机采集小麦冠层图像时,自然环境影响和人为操作可能会导致图像出现对比度不足、色偏等问题,进而影响图像特征的提取以及氮素含量估算

的精度。为纠正图像的色差，采用伽马校正法进行白平衡处理。其次，田间拍摄的无人机图像会带有土壤、秸秆和阴影等噪声。植被指数是识别图像中植被区域与非植被区域的有效方法。为有效去除噪声并尽可能保留小麦冠层图像颜色特征信息，本文采用基于植被指数的阈值分割法对无人机 RGB 图像进行预处理，处理前后对比如图 4 所示。

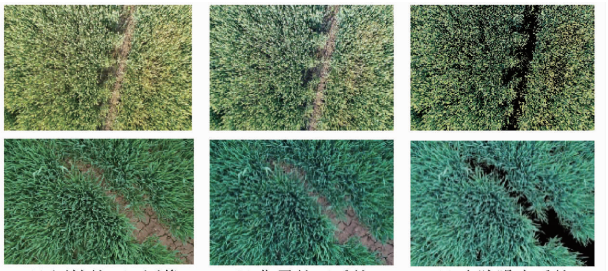

(a) 原始的RGB图像　(b) 伽马校正后的RGB图像　(c) 去除噪声后的RGB图像

图 4　无人机 RGB 图像的预处理结果

Fig. 4　Pre-processing results of UAV images

1.3　算法原理

1.3.1　深度信念网络

深度信念网络(Deep belief network, DBN)是一类基于概率图模型的生成式深度学习模型，其结构由多个通过无监督预训练的受限玻尔兹曼机(Restricted Boltzmann machine, RBM)逐层堆叠而成[18]。RBM 模型是一个由可见层和一个隐藏层组成的两层神经网络结构，该结构中的神经元在层内相互独立，但层与层之间通过对称的无向权重连接，从而形成一个无向图模型，如图 5 所示。

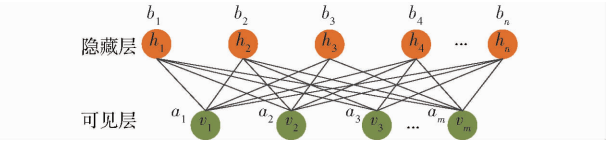

图 5　RBM 模型结构图

Fig. 5　Structure diagram of RBM model

在 RBM 模型中，设 $\boldsymbol{w}$ 为可见层和隐藏层之间的连接权重，$\boldsymbol{h}$ 为隐藏层的状态向量，$\boldsymbol{v}$ 为可见层的状态向量，$\boldsymbol{a}$ 和 $\boldsymbol{b}$ 分别表示可见层和隐藏层的偏置向量。则其能量函数表达式为

$$E_\theta(\boldsymbol{v},\boldsymbol{h}) = -\sum_{i=1}^{m} a_i v_i - \sum_{i=1}^{n} b_j h_j - \sum_{i=1}^{m}\sum_{j=1}^{n} h_j w_{ij} v_i \tag{1}$$

其中　$\theta = \{w, a, b\}$

式中　v_i——可见单元

h_j——隐藏单元

w_{ij}——可见单元 v_i 和隐藏单元 h_j 间的连接权重

a_i——可见层第 i 个神经单元的偏置系数

b_j——隐藏层第 j 个神经单元的偏置系数

θ——网络参数

根据能量函数，计算 $\{\boldsymbol{v},\boldsymbol{h}\}$ 的联合概率分布函数 $P_\theta(\boldsymbol{v},\boldsymbol{h})$。

$$P_\theta(\boldsymbol{v},\boldsymbol{h}) = \frac{1}{z_\theta} e^{-E_\theta(\boldsymbol{v},\boldsymbol{h})} \tag{2}$$

其中　$$z_\theta = \sum_{\boldsymbol{v},\boldsymbol{h}} e^{-E_\theta(\boldsymbol{v},\boldsymbol{h})}$$

式中　z_θ——归一化因子，代表所有变量能量函数的代数和

可见层向量 $\boldsymbol{v}$ 和隐藏层向量 $\boldsymbol{h}$ 的条件概率为 $P_\theta(\boldsymbol{v},\boldsymbol{h})$ 的边缘分布，也称为似然函数，计算公式分别为

$$P_\theta(\boldsymbol{v}) = \frac{1}{z_\theta}\sum_{\boldsymbol{h}} e^{-E_\theta(\boldsymbol{v},\boldsymbol{h})} \tag{3}$$

$$P_\theta(\boldsymbol{h}) = \frac{1}{z_\theta}\sum_{\boldsymbol{v}} e^{-E_\theta(\boldsymbol{v},\boldsymbol{h})} \tag{4}$$

深度信念网络模型训练包括 2 个阶段[19]：

(1)自下而上对每个由($\boldsymbol{v},\boldsymbol{h}$)组成的 RBM 逐层进行无监督的预训练，提取高阶特征表示。

RBM 的训练目标是最大化观测数据在模型下的对数似然函数 $\ln p_\theta(\boldsymbol{v})$。采用 Contrastive Divergence (CD)算法，其核心是利用有限步 Gibbs 采样近似负相梯度，逐步更新参数以逼近最大似然估计。每层 RBM 预训练的过程如下：

①正向采样。根据第 k 层的初始可见向量 $\boldsymbol{v}^{k(0)}$ 计算隐藏层第 j 个隐藏单元 h_j 的激活概率，计算公式为

$$P(h_j = 1 \mid \boldsymbol{v}^{k(0)}) = \text{Sigmoid}\left(\sum_{i=1}^{m} w_{ij} v_i^{k(0)} + b_j\right) \tag{5}$$

然后根据 Gibbs 采样方法得到第 k 层隐藏单元 $h_j^{k(0)}$，$h_j^{k(0)} \sim p(h_j \mid \boldsymbol{v}^{k(0)})$。

②从隐藏层向量 $\boldsymbol{h}^{k(0)}$ 进行可见层向量 $\boldsymbol{v}^{k(0)}$ 的反向重构 $\boldsymbol{v}^{k(1)}$。反向重构中可见层单元 v_i 概率计算公式为

$$P(v_i = 1 \mid \boldsymbol{h}^{k(0)}) = \text{Sigmoid}\left(\sum_{j=1}^{n} w_{ij} h_j^{k(0)} + a_i\right) \tag{6}$$

仍然根据 Gibbs 采样方法得到第 k 层可见层单元 v_i^k 的重构，$v^{k(1)} \sim p(v_i \mid \boldsymbol{h}^{k(0)})$。再次计算重构后的隐层激活概率，更新隐藏层向量 $\boldsymbol{h}^{k(1)}$，计算公式为

$$P(h_j = 1 \mid \boldsymbol{v}^{k(1)}) = \text{Sigmoid}\left(\sum_{i=1}^{m} w_{ij} \boldsymbol{v}_i^{k(1)} + b_j\right) \tag{7}$$

③进行参数更新，计算公式为

$$\begin{cases} \Delta w_{ij} = \eta[\langle v_i h_j\rangle_{\text{data}} - \langle v_i h_j\rangle_{\text{recon}}] \\ \Delta a_i = \eta[(v_i)_{\text{data}} - (v_i)_{\text{recon}}] \\ \Delta b_j = \eta[(h_j)_{\text{data}} - (h_j)_{\text{recon}}] \end{cases} \tag{8}$$

式中　$v_i^{k(0)}$——第 k 层的第 i 个初始可见单元

$h_j^{k(0)}$——第 k 层第 j 个隐藏单元

$v_i^{k(1)}$——第 k 层的第 i 个重构后可见单元

$h_j^{k(1)}$——第 k 层第 j 个重构隐藏单元

η——RBM 学习率

$\langle v_i h_j \rangle_{\text{data}}$——真实数据驱动下，可见单元 v_i 与隐藏单元同时被激活的频率

$\langle v_i h_j \rangle_{\text{recon}}$——在重构数据中，可见单元 v_i 与隐藏单元同时被激活的频率

以真实原始数据为驱动在学习完第 1 层 RBM，所产生的激活隐藏状态就成为学习第 2 层 RBM 的可见层输入，运行 CD 算法独立训练当前 RBM 的参数 w。逐层学习直到将最顶层的 RBM 训练完成。

(2)有监督微调。

将预训练好的 DBN 作为一个前馈神经网络进行初始化，加入标签数据，使用传统的反向传播算法对整个网络进行有监督微调。

1.3.2 VGG16 神经网络

VGG16 是经典卷积神经网络[20]，由 5 个卷积块、3 个全连接层和 1 个 Softmax 层构成。该网络使用连续多个 3×3 的卷积核替代了 5×5 和 7×7 的大卷积核，扩大了感受野并提高了网络的非线性表达能力。在每个卷积块后进行最大池化 2×2 运算，降低空间维度。具有 16 层权重层，特征提取能力更强，易于提取到图像不同位置的边缘特征。所有隐藏层使用 ReLU 激活函数，加快收敛速度的同时提升非线性能力。

1.3.3 通道注意力机制

SE(Squeeze-and-Excitation network)通道注意力机制[21]由挤压(Squeeze，F_{sq})和激发(Excitation，F_{ex})两步组成，如图 6 所示。挤压操作对输入尺寸为 $H \times W \times C$ 的特征图进行全局平均池化，得到 $1 \times 1 \times C$ 的特征向量从而获得全局感受野。激发操作通过两层全连接层(第 1 层降维，第 2 层升回原通道数)及 ReLU 激活函数，接着通过 Sigmoid 函数生成每个通道的权重。最后将生成的权重向量与原特征图逐通道相乘，实现对重要特征通道的增强和次要通道的抑制。

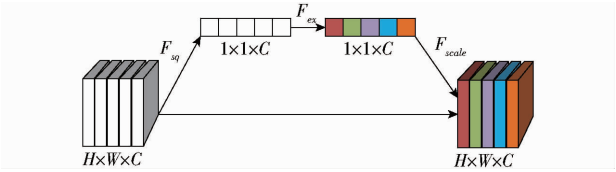

图 6 SE 注意力模块

Fig. 6 SE attention module

2 双模态特征融合小麦氮素含量估算模型

2.1 小麦氮素含量估算模型

本文构建了双模态小麦氮素含量估算模型。采用深度信念网络 DBN 对人工计算的小麦冠层图像特征与土壤环境参数进行联合学习，以深度挖掘与氮素含量相关的多源非线性关系。采用改进后的 VGG16 卷积神经网络，从无人机获取的小麦冠层图像中自动提取高维、深层的图像特征。最后利用 BP 神经网络对 DBN 与改进 VGG16 网络所提取的不同特征进行融合学习，实现对小麦叶片氮素含量的高精度估计，网络结构如图 7 所示。

无人机拍摄的小麦冠层图像具有高相似性，使用经典 VGG16 网络提取特征时计算量大且存在冗余信息。本文对 VGG16 网络进行改进，在原始网络每个卷积层中将最后 1 个 3×3 卷积核替换为 3 个 1×1 卷积核，以降低计算量并增强非线性特征表达能力。同时在最后一个卷积层后引入 SE 注意力机制，使网络更聚焦于与小麦氮素含量高度相关的特征，抑制无关信息。全连接层的神经元节点数依次设为 2 048、1 024、512 和 128，输出 128 维的特征向量。

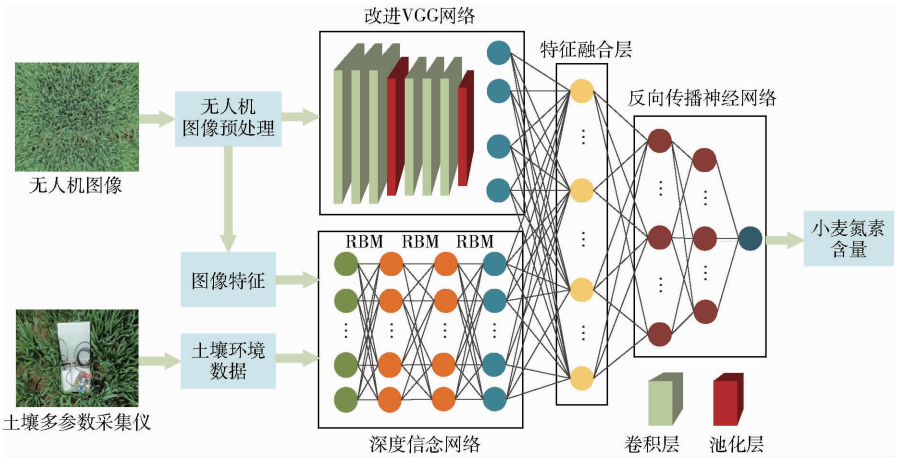

图 7 双模态特征融合小麦氮素含量估算模型结构

Fig. 7 Structure of a dual-modality feature fusion model for estimating nitrogen content in wheat

建立的深度信念网络包括 3 个 RBM 层和 1 个 BP 层，RBM 隐藏层的神经元的数量分别为 32、64、32，BP 层的神经元个数为 32。

2.2　RGB 图像特征与土壤环境参数筛选

2.2.1　小麦冠层 RGB 图像特征计算

RGB 图像不仅包含作物的颜色、纹理特征，还可派生出多种植被指数[22]。其中，图像颜色特征用于描述目标表面的颜色组成与分布特性，最常用的包括红、绿、蓝三通道的均值等指标，广泛应用于无人机遥感中。植被指数实质上是对 RGB 图像的通道信息进行数学组合，以构造能反映植被生理状态的特征变量，在作物氮素含量估算中具有重要应用价值。为系统分析小麦冠层 RGB 图像与其氮素含量的关系，本文参考文献[23－27]，选取了 20 种典型的 RGB 图像特征，包括 10 种图像颜色特征与 10 种植被指数，其具体特征为红色通道值 r[23]、绿色通道值 g[23]、蓝色通道值 b[23]、红光归一化比值 R[24]、绿光归一化比值 G[24]、蓝光归一化比值 B[24]、绿红通道比值 G/R[25]、红蓝通道比值 R/B[25]、绿蓝通道比值 G/B[25]、绿红通道差值 GMR[25]、绿红植被指数 GRVI[25]、可见光大气阻抗植被指数 VARI[25]、超红植被指数 ExR[25]、超绿植被指数 ExG[25]、绿叶指数 GLI[25]、绿红差值指数 ExGR[26]、改良绿红植被指数 MGBVI[26]、红绿蓝植被指数 RGBVI[26]、归一化差分指数 NDI[26]、沃贝克指数 WI[27]。

2.2.2　不同特征与小麦氮素含量的相关性分析

最大相关熵（Maximum correntropy criterion，MCC）是一种用于衡量变量相关性的度量函数，能够有效处理非线性高斯特性的相关性问题，并广泛应用于数据降维与特征选择[28]。本文基于相关熵分析法，对实验室检测的小麦叶片氮素含量与不同生长时期的 20 种小麦冠层图像特征及 6 种土壤环境参数（温度、含水率、氮含量、磷含量、钾含量、pH 值）进行了相似性计算，以筛选出不同生长期氮素含量估算的优势特征。

多次重复试验表明，当相关熵系数阈值设为 0.7 时，模型决定系数 R^2 达到最大，估算精度最佳。因此，本文选取相关熵系数大于 0.7 的特征作为估算模型输入。以图 8 为例，小麦灌浆期相关熵系数大于 0.7 的图像特征包括 GMR、R/B、G/B、G/R、RGBVI、VARI 和 GLI，土壤环境参数包括 pH 值、含水率、氮含量、磷含量和钾含量。在小麦起身期，除上述特征外，MGRVI、ExR 和土壤温度也满足相关熵系数大于 0.7 的筛选标准。

2.2.3　输入特征最优组合筛选

为筛选出双模态小麦氮素含量估算模型中文本

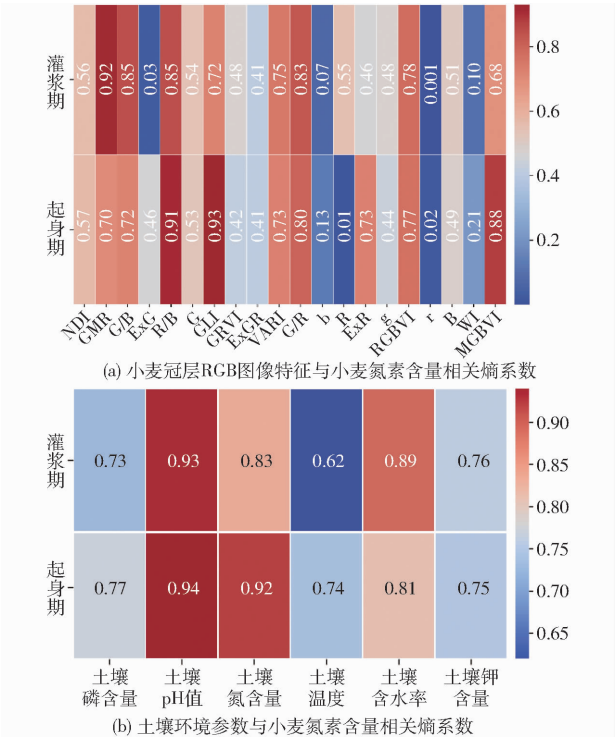

图 8　不同特征与小麦氮素含量的相关熵系数

Fig. 8　Entropy coefficients of different characteristics related to nitrogen content in wheat

模态最优输入特征组，采用 BP 神经网络构建特征筛选回归模型。结合 2.2.2 节的计算结果，并考虑小麦在不同生长期相关熵系数的差异，取灌浆期和起身期 2 个时期对应特征的相关熵系数的均值作为初始特征排序依据，各备选特征在 2 个生长期的相关熵均值如图 9 所示。

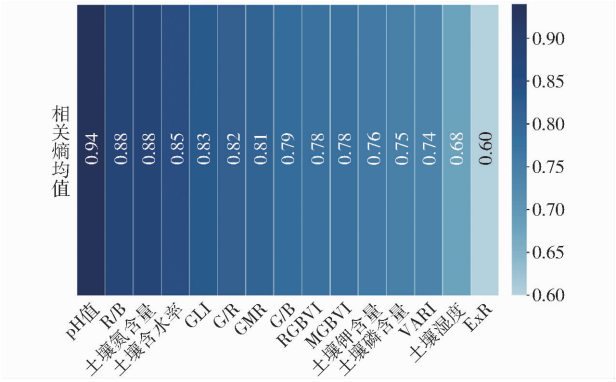

图 9　各个特征在小麦 2 个生长时期相关熵均值

Fig. 9　Mean correlated entropy of each feature across two growth stages of wheat

回归试验结果如图 10 所示。随着输入特征数量增加，小麦 2 个生长期的估算精度均呈上升趋势，决定系数 R^2 随之提高。当输入特征数量为 12 个时，平均 R^2 达到最大值 0.736。由此确定最优估算特征组合，包括 7 种图像颜色特征（R/B、GLI、G/R、GMR、G/B、RGBVI、MGBVI）及 5 种土壤环境参数（pH 值、氮含量、含水率、钾含量、磷含量）。

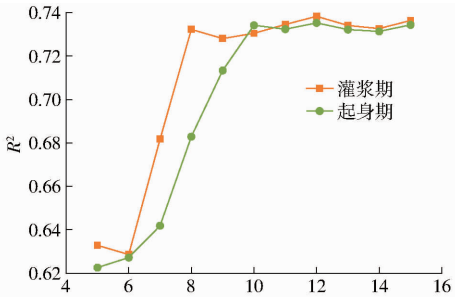

图 10 小麦氮素含量估算 R^2 变化曲线

Fig. 10 Trend chart of R^2 for predicted nitrogen content in wheat

2.3 样本集构建

本文田间实测数据包括 100 份小麦灌浆期图像和 200 份小麦起身期图像以及对应的田间土壤环境数据,属于小样本数据集。为提高氮素含量估算模型的精度与泛化能力,需要对数据进行增强。

将试验田的每个地块平均划分为 9 份,对于无人机获取的冠层图像,通过图像裁剪将每幅地块图像切分为 9 幅等尺寸子图,对应地块划分的 9 个小地块,从而将图像数据扩充为原始数据集的 9 倍。

在小麦的同一生长时期,通过多次重复试验和相关性计算发现,相邻地块的土壤环境参数之间普遍具有较高的空间相似性,叶片氮素含量检测值之间亦表现出类似特征。在此基础上,本文提出了一种基于空间邻近性插值的样本增强方法。具体做法是:将每个地块划分为 3×3 九宫格,其中中心格子对应该地块实测的原始数据,其余 8 个格子则代表需要生成的新样本区域,如图 11 中绿色五角星所示,与无人机裁剪后的图像相对应。借鉴合成少数类过采样技术(Synthetic minority oversampling technique,SMOTE)[29]"相似性插值"的思想,通过在当前地块中心位置的实测数据和其他 8 个方向相邻地块的中心位置实测数据之间建立线性插值方法生成新的样本,数据增强方法示意图如图 11 所示。计算公式为

$$x_{new} = x_i + \mathrm{rand}(0,1) \mid x_i - x_{ij} \mid \tag{9}$$

式中 x_{new}——新合成样本

x_i——当前原始样本

x_{ij}——第 j 个近邻样本

$\mathrm{rand}(0,1)$——产生 0 到 1 随机数的函数

若当前需要进行数据增强的地块位于麦田的 4 个对角线顶点位置,如图 11b 所示,当前原始样本仅有 3 个邻近样本,可以通过这 3 个邻近样本生成其他 8 个新样本。若当前需要进行数据增强的地块位于麦田的 4 个边线位置,原始样本仅有 5 个邻近样本,可以通过这 5 个邻近样本生成其他 8 个新样本。

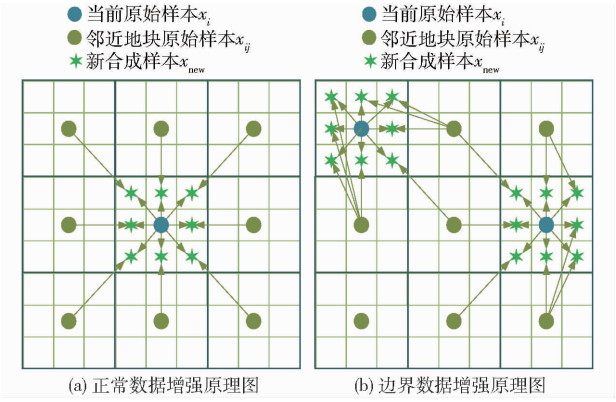

图 11 基于 SMOTE 算法的数据增强原理图

Fig. 11 Schematics of data enhancement based on SMOTE algorithm

通过图像裁剪和改进 SMOTE 算法进行数据扩充后,灌浆期数据从 100 份扩展至 900 份,起身期数据从 200 份扩展至 1 800 份。

2.4 评价指标

本文选取决定系数(Coefficient of determination,R^2)、均方误差(Mean square error,MSE)以及平均绝对误差(Mean absolute error,MAE)作为小麦氮素含量估算方法的评价指标,R^2 反映估算模式因变量变化可靠程度,以此来判断估算模型的解释力。MSE 是估算值与真实值偏差的平方和与样本个数 n 比值,用来衡量估算值同真实值之间的偏差。MAE 是估算值与真实值的绝对值误差与样本个数的比值。R^2 取值范围为[0,1],模型的 R^2 值越接近 1,说明模型的估算精度越高,MSE 和 MAE 值越小,说明模型的估算效果越好。

3 试验

3.1 试验环境配置与模型训练

模型训练与测试在工作站环境下进行,操作系统为 Windows 10,硬件配置为 NVIDIA GeForce RTX4090 16GB GPU,并通过 CUDA 11.6 调用 GPU 加速训练。算法开发采用 Python 3.9,深度学习框架为 PyTorch 2.0.1。网络权重的学习采用随机梯度下降(Stochastic gradient descent, SGD)算法,训练过程中结合 Adam 方法进行权重优化。主要超参数设置如表 1 所示。

小麦叶片氮素含量估算模型的试验样本包括数据增强后得到的 900 份灌浆期样本和 1 800 份起身期样本,每份样本包含无人机拍摄的冠层图像、7 种图像特征及 5 种土壤环境参数。为验证双模态深度学习模型在不同生长时期的泛化能力,将数据集划分为 4 种类型,如表 2 所示。并按比例 7∶3 划分为训练集与测试集,用于估算不同生长期的小麦氮素含量。

表 1　神经网络训练的参数配置

Tab. 1　Parameter configuration for neural network training

参数	数值
VGG16 改进 1×1 卷积核	15
VGG16 全连接层神经元	[2 048,1 024,512,128]
RBM 隐藏层神经元	[32,64,32]
BP 神经元	32
迭代次数	500
批大小	10
学习率	0.001

表 2　小麦氮素含量估算数据集

Tab. 2　Wheat nitrogen content prediction dataset

数据集	小麦灌浆期数据量	小麦起身期数据量	数据总量
小麦灌浆期数据集	900	0	900
小麦起身期数据集	0	900	900
小麦全生长时期数据集 1	450	450	900
小麦全生长时期数据集 2	900	1 800	2 700

在小麦全生长时期数据集 2 上进行估算模型的训练时，损失函数随迭代次数变化的收敛曲线如图 12 所示，模型在训练 50 轮后迅速收敛，100 轮时已基本收敛，至 500 轮时损失函数值几乎不再变化，表明模型已充分收敛。

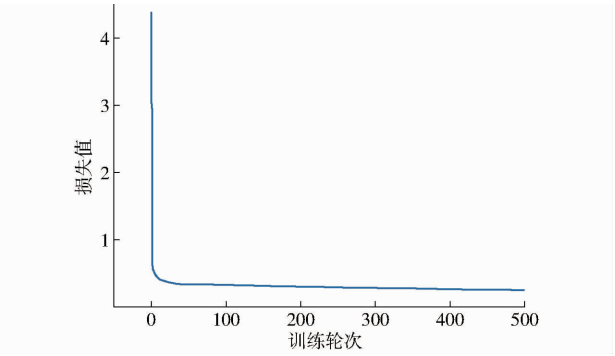

图 12　小麦氮素含量估算模型训练损失函数收敛曲线

Fig. 12　Convergence curve of training loss function for wheat nitrogen content estimation model

3.2　双模态小麦氮素含量估算模型结果分析

3.2.1　双模态特征提取输出神经元数对模型估算精度的影响分析

双模态小麦氮素含量估算模型采用改进 VGG16 的卷积神经网络提取无人机小麦冠层图像的特征，采用 DBN 网络对土壤环境参数和计算的图像特征进行学习，然后将 2 种特征输入特征融合层。输入到特征融合层的神经元数目比例不同会对估算结果产生较大的影响，为了确定 2 种模态最佳输入神经元数目的比例，分别设置不同的 VGG16 和 DBN 网络特征输出层神经元的个数，在小麦全生长时期数据集 2 上进行试验。从图 13 中可以看出当 VGG16 和 DBN 输出层的神经元个数分别为 128 和 32 时，小麦氮素含量估算精度最高，此时双模态小麦氮素含量估算模型的 R^2、MSE 以及 MAE 分别为 0.927、0.312 g/kg 和 0.363 g/kg。

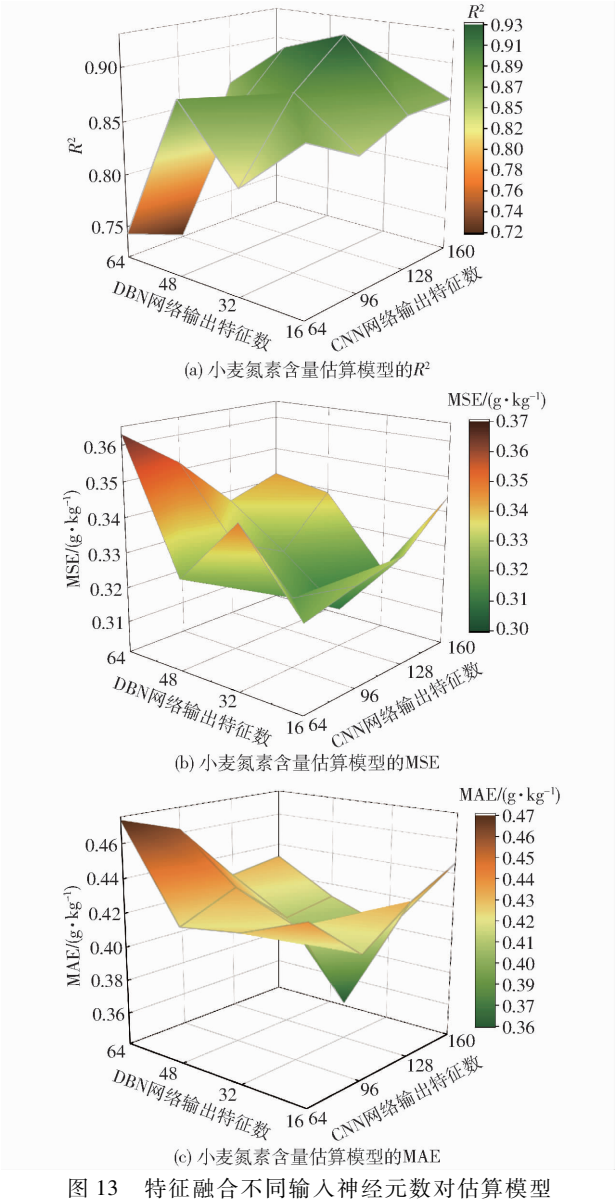

图 13　特征融合不同输入神经元数对估算模型精度影响

Fig. 13　Effect of different input neuron counts in feature fusion on estimating model accuracy

3.2.2　双模态估算模型在不同数据集估算结果分析

小麦在不同生长时期的氮素含量存在显著差异，为验证双模态氮素含量估算模型在小麦不同生长时期的估算准确性，分别在小麦灌浆期数据集、小麦起身期数据集及小麦全生长时期数据集 1 上进行训练和测试。3 个数据集的样本量均为 900。

表 3 展示了不同数据集下估算模型的性能评价结果。试验结果表明，估算模型在小麦灌浆期数据

集上的估算精度最高，R^2、MSE 和 MAE 分别为 0.927、0.212 g/kg 和 0.236 g/kg。小麦全生长期数据集 1 的估算精度 R^2 为 0.921，估算误差 MSE 为 0.395 g/kg，MAE 为 0.423 g/kg，与灌浆期数据集相比，R^2 仅下降 0.006，MSE 和 MAE 分别仅增加了 0.183 g/kg 和 0.187 g/kg。总体来看，在 3 个数据集上 R^2 平均为 0.924，误差 MSE 和 MAE 平均为 0.327 g/kg 和 0.361 g/kg，远远小于实测小麦叶片氮素含量的误差范围，表明本文提出的双模态小麦氮素含量的估算模型能够准确估算小麦不同生长期的氮素含量。图 14 展示了在小麦全生长期数据集 1 上估算数据和实测数据的对比，可以发现试验结果表现出较高的一致性与拟合度。

表 3 双模态估算模型在不同数据集上的估算结果

Tab. 3 Prediction results of bimodal prediction models on different datasets

数据集	R^2	MSE/(g·kg^{-1})	MAE/(g·kg^{-1})
小麦灌浆期数据集	0.927	0.212	0.236
小麦起身期数据集	0.924	0.374	0.426
小麦全生长期数据集 1	0.921	0.395	0.423

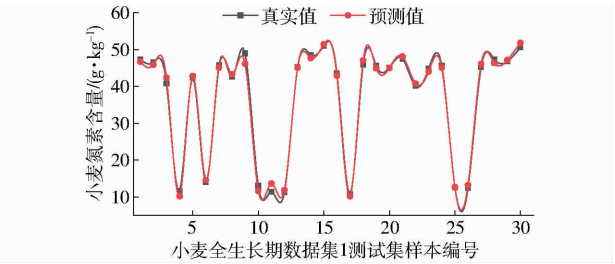

图 14 小麦全生长期数据集 1 测试集预测值与真实值对比

Fig. 14 Comparison of actual and predicted values across different test datasets

3.2.3 双模态与单模态估算模型对比分析

为验证本文所提双模态特征提取与融合方法在小麦氮素含量估算中的精度提升效果，分别将改进 VGG16 网络提取的深层次图像特征与 DBN 网络学习的文本特征，作为 BP 神经网络的输入，进行单模态小麦叶片氮素含量估算。所用数据集为小麦全生长时期数据集 2。图 15 展示了单模态与双模态模型在小麦氮素含量估算中的性能对比。

从图 15 中可以看出，双模态估算模型相比单 DBN 模型，R^2 提高了约 2.65%，MSE 和 MAE 分别降低了约 60.4% 和 32.3%。相比改进 VGG16 估算模型，R^2 提高了约 3.92%，MSE 和 MAE 分别降低了约 64.4% 和 38.1%。结果表明，双模态小麦叶片氮素含量估算模型在融合多源特征后可获取更全面的信息，从而表现出更优的估算性能。

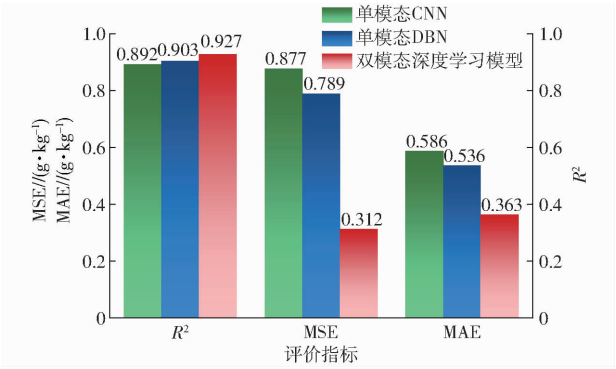

图 15 双模态与单模态估算模型结果对比

Fig. 15 Comparison of results between dual-modality and single-modality estimation models

3.2.4 不同估算模型试验结果对比分析

为进一步验证本文提出的双模态氮素含量估算模型的有效性，将其与最近 2 年相似文献[30－32]氮素含量估算方法进行对比分析。文献[30]利用无人机采集的棉花冠层 RGB 图像，构建二维 CNN 估算模型，以实现棉花冠层氮素含量的估算。文献[31]采用无人机获取水稻生长期冠层 RGB 图像，手动提取 11 种植被指数特征，并采用自适应增强结合人工神经网络、偏最小二乘法(PLS)和随机森林(RF)等 6 种机器学习算法对氮素含量进行估算。本文选用其中精度最高的 RF 方法进行对比试验分析。文献[32]通过提取无人机图像的植被指数特征及其颜色矩阵，构建偏最小二乘回归(PLSR)模型对水稻氮素含量进行估计。

对比试验均在小麦全生长时期数据集 2 上进行。测试结果的性能评价指标值如表 4 所示，本文所提出的估算方法的性能显著优于文献方法，R^2 达到了 0.927，MSE 和 MAE 分别为 0.312 g/kg 和 0.363 g/kg，远远小于小麦氮素含量实测值。与文献[30]相比，R^2 提高了约 3.92%，MSE 和 MAE 分别降低了约 63.6% 和 58.5%。与文献[31]相比，R^2 提高了约 4.98%，MSE 和 MAE 分别降低了约 57.5% 和 55.8%。与文献[32]相比，R^2 提高了 5.58%，MSE 和 MAE 分别降低了约 62.3% 和 59.8%。这表明本文双模态估算模型在作物氮素含量估算中具有更优的性能。

表 4 双模态估算模型与现有文献方法对比结果

Tab. 4 Comparison results of bimodal prediction model with existing literature methods

模型	R^2	MSE/(g·kg^{-1})	MAE/(g·kg^{-1})
文献[30]	0.892	0.856	0.874
文献[31]	0.883	0.734	0.821
文献[32]	0.878	0.828	0.903
本文方法	0.927	0.312	0.363

图 16 展示了采用文献[30－32]以及本文所提估算模型在小麦全生长期数据集 2 的测试集上的估算值与真实值的对比，本文模型能更好地捕捉到小麦生长过程中氮素含量变化规律。图 17 展示了本文所提估算模型的小麦氮素含量估算值与实测值的 1∶1比较结果。结果显示，估算数据大多分布在对角线附近，验证了模型的较高估算精度。

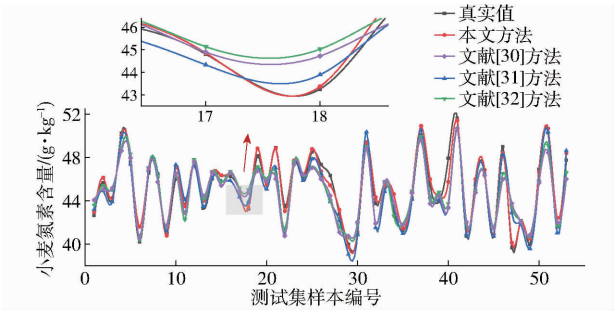

图 16　双模态估算模型与现有文献方法估算结果对比

Fig. 16　Comparison of prediction results between dual-modality prediction model and existing literature methods

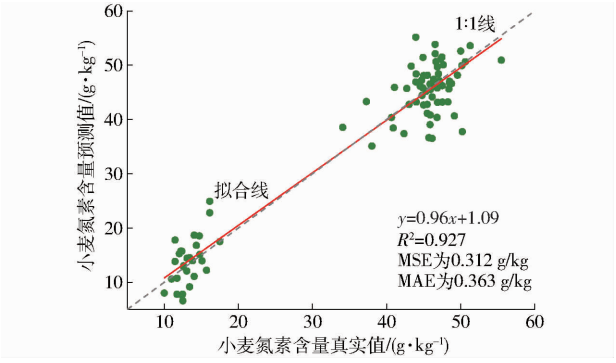

图 17　双模态估算模型估算值与实测值对比

Fig. 17　Comparison of predicted values from dual-modality prediction model and actual measured values

3.3　双模态估算模型的系统应用

将训练完成的双模态小麦氮素含量估算模型以接口形式集成至自主研发并部署于阿里云的智慧农田管理系统中，为用户提供基于浏览器的冬小麦氮素含量估算服务。用户通过浏览器提交目标地块的土壤环境数据（温度、含水率、pH 值和氮磷钾含量）和小麦冠层图像后，系统将数据传输至深度学习服务器进行处理：对图像进行白平衡与分割，提取图像特征，并结合土壤数据输入模型生成氮素含量估算结果。结果可在浏览器端实时显示，并同步存储至系统数据库，整个流程约耗时 20 s，结果如图 18 所示。该方法能够直观、快速且无损地获取小麦营养状况，实现对不同生长期小麦养分水平的实时诊断，并为施肥管理和追肥策略提供科学依据。

4　讨论

本文提出的双模态小麦氮素含量估算模型，在



(a) 智慧农田系统首页　　(b) 小麦氮素估算应用

图 18　双模态估算模型的系统应用

Fig. 18　System application of dual-modality prediction model

性能上优于仅依赖无人机 RGB 图像（文献[30]）和基于 RGB 图像提取的颜色、纹理特征的单模态估算模型（文献[31－32]）。单模态估算模型仅能捕捉作物冠层的颜色、纹理等图像的浅层信息，而作物氮素含量还会直接受土壤氮、磷、钾含量及 pH 值等因素的影响。导致单模态模型难以充分提取和学习影响叶片氮素含量变化的特征。本文提出的双模态估算模型一方面通过改进 VGG16 网络提取冠层 RGB 图像的形态与纹理等复杂信息，同时利用 DBN 网络学习土壤环境参数对小麦氮素含量的影响，能够捕捉氮素含量的多源非线性关系，从而实现更全面、精确的估算。估算结果与宋晓等[33]在冬小麦估测研究中结论基本一致。

本文建立的小麦氮含量估算模型，在训练阶段采用了九宫格裁剪与邻域插值方法对小样本数据集进行了有效的数据扩充。使估算模型在小范围试验区域，冬小麦 2 个关键生长期与全生长周期的叶片氮素含量估算的精度平均 R^2 达到 0.92，满足估算模型的精度要求。目前的研究工作正在开展用起身期数据对模型进行训练，将灌浆期数据作为模型的测试数据集和反向验证的独立外推试验。由于成本和作物生长期等原因，本阶段的研究没有在试验田外的麦田区域采集小麦植株进行化学方法检验，以获取氮素含量估算所需的对比标签，也就无法利用估算模型进行跨采集区时空外推验证。后续开展的小麦氮素含量估算研究中，将开展跨采集区的时空外推试验，以便对估算模型进行更准确的性能评估以及模型优化。

此外，需要指出的是，本文提出的小麦氮素含量估算模型还处于具体农业应用的试验阶段，尚缺乏田间验证。后期研究将开展叶片氮素含量估算结果与作物栽培阈值之间的关联分析。临界氮浓度 N_c 是诊断作物氮营养状况的重要阈值[34]，未来工作将结合本研究区冬小麦叶片干物质建立对应的临界氮浓度 N_c 曲线，将小麦氮素含量的估算值与 N_c 值进行对比分析，评估作物氮素营养状况，为建立科学的测土配方提供数据基础。

5 结论

(1)利用无人机搭载高清 RGB 相机获取小麦起身期和灌浆期的 RGB 图像,利用双模态思想融合 RGB 图像、图像特征以及土壤环境参数,构建了基于深度学习方法的小麦氮素含量的估算模型。

(2)无人机采集小麦冠层图像,预处理后计算图像特征,利用自主研发的便携式土壤多参数采集仪实时采集麦田土壤环境数据。通过最大相关熵分析和 BP 神经网络建立特征筛选的回归模型,确定了估算小麦冠层氮素含量的最优特征组合,包括 7 种图像特征和 5 种土壤环境参数。

(3)基于筛选出的特征集,融合 RGB 小麦冠层图像,构建了双模态特征融合的小麦冠层氮素含量估算模型。模型中使用改进的 VGG16 网络提取小麦冠层图像的深层表征特征,建立 DBN 网络学习筛选出的与氮素含量高相关性的特征数据,最终通过 BP 神经网络输出氮素含量估算值。

(4)试验结果显示,该模型的 R^2 为 0.927,均方误差(MSE)为 0.312 g/kg,平均绝对误差(MAE)为 0.363 g/kg,展现出较好的估算精度和鲁棒性,能够较好地估算冬小麦氮素含量,为监测冬小麦生长营养状况提供一种可行的智能方法和实际应用的示范。

参 考 文 献

[1] 付波霖,孙军,李雨阳,等. 基于多光谱影像和机器学习算法的红树林树种 LAI 估算[J]. 农业工程学报,2022,38(7):218 - 228.
Fu Bolin, Sun Jun, Li Yuyang, et al. Mangrove LAI estimation based on remote sensing images and machine learning algorithms [J]. Transactions of the CSAE, 2022, 38(7): 218 - 228. (in Chinese)

[2] Walsh O S, Shafian S, Marshall J M, et al. Assessment of UAV based vegetation indices for nitrogen concentration estimation in spring wheat[J]. Advances in Remote Sensing, 2018, 7(2): 71 - 90.

[3] 张玲,陈新平,贾良良. 基于无人机可见光遥感的夏玉米氮素营养动态诊断参数研究[J]. 植物营养与肥料学报,2018,24(1):261 - 269.
Zhang Ling, Chen Xinping, Jia Liangliang. Parameter research of using UAV-based visible spectral analysis technology in dynamical diagnosis of nitrogen status of summer maize[J]. Journal of Plant Nutrition and Fertilizers, 2018,24(1):261 - 269. (in Chinese)

[4] Kavaliauskas A, Žydelis R, Castaldi F,et al. Predicting maize theoretical methane yield in combination with ground and UAV remote data using machine learning[J]. Plants, 2023, 12(9):2223 - 7747.

[5] Peng X, Chen D, Zhou Z, et al. Prediction of the nitrogen, phosphorus and potassium contents in grape leaves at different growth stages based on UAV multispectral remote sensing[J]. Remote Sensing, 2022, 14(11): 2659.

[6] 叶春,刘莹,刘继忠,等. 基于 LBPHSV + ResNet50 融合的水稻冠层氮素营养监测方法[J]. 中国农业大学学报,2023,28(1):39 - 47.
Ye Chun, Liu Ying, Liu Jizhong, et al. A method for monitoring nitrogen nutrition in rice canopy based on LBPHSV + ResNet50 fusion[J]. Journal of China Agricultural University,2023,28(1):39 - 47. (in Chinese)

[7] 梁晋,刘仕元,王帅彬,等. 基于无人机遥感的花生氮营养反演研究[J]. 中国油料作物学报,2020,42(6):1043 - 1050.
Liang Jin, Liu Shiyuan, Wang Shuaibin, et al. Peanut nitrogen nutrition inversion based on unmanned aerial vehicle remote sensing[J]. Chinese Journal of Oil Crop Sciences, 2020,42(6):1043 - 1050. (in Chinese)

[8] 汪晓丽,陈平,封克. 酸性环境下作物幼苗对 NO_3^--N 和 NH_4^+-N 的吸收特征[J]. 扬州大学学报(农业与生命科学版),2007,28(2):52 - 56.
Wang Xiaoli, Chen Ping, Feng Ke. Uptake characteristics of NO_3-N and NH_4^+-N by different plant seedlings under the low pH condition[J]. Journal of Yangzhou University (Agricultural and Life Science Edition), 2007,28(2):52 - 56. (in Chinese)

[9] Djaman K, Irmak S, Martin D L, et al. Plant nutrient uptake and soil nutrient dynamics under full and limited irrigation and rainfed maize production[J]. Agronomy Journal, 2013, 105(2): 527 - 538.

[10] 张宗祥,吴雪凡,刘楠楠,等. 土壤酸化对玉米产量、氮代谢及相关基因表达的影响[J]. 华北农学报,2022,37(3):94 - 103.
Zhang Zongxiang, Wu Xuefan, Liu Nannan, et al. Effects of soil acidification on Yie, nitrogen metabolism, and related gene expression of maize[J]. Acta Agriculturae Boreali-Sinica, 2022,37(3):94 - 103. (in Chinese)

[11] Ngiam J, Khosla A, Kim M, et al. Multimodal deep learning[C]// Proceedings of the 28th International Conference on Machine Learning (ICML - 11), 2011: 689 - 696.

[12] Lu J, Cheng D, Geng C, et al. Combining plant height, canopy coverage and vegetation index from UAV-based RGB images to estimate leaf nitrogen concentration of summer maize[J]. Biosystems Engineering, 2021,202(2):42 - 54.

[13] 李道亮,赵晔,杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报,2025,56(1):1 - 15.
Li Daoliang,Zhao Ye,Du Zhuangzhuang. Advances in multi-modal fusion techniques and applications in agricultural field[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(1):1 - 15. (in Chinese)

[14] Li C, Li X, Meng X, et al. Hyperspectral estimation of nitrogen content in wheat based on fractional difference and continuous

wavelet transform[J]. Agriculture, 2023, 13(5): 1017.
[15] Liu H, Zhu H, Wang P. Quantitative modelling for leaf nitrogen content of winter wheat using UAV-based hyperspectral data [J]. International Journal of Remote Sensing, 2017, 38(8): 2117 - 2134.
[16] 冀汶莉,王佳豪,王新伟. 基于 LoRa 的农业大田土壤多参数监测系统设计[J]. 无线电工程,2023,53(2):456 - 464.
Ji Wenli, Wang Jiahao, Wang Xinwei. Design of multi-parameter monitoring system of agricultural field soil based on LoRa [J]. Radio Engineering, 2023,53(2):456 - 464. (in Chinese)
[17] 刘洲,冀汶莉,王佳豪. 一种农作物检测系统:中国, ZL 202122247031.5[P]. 2022 - 04 - 19.
[18] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527 - 1554.
[19] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006,313(7):504 - 507.
[20] Karen S, Andrew Z. Very deep convolutional networks for large-scale image recognition[PP/OL]. V1. arXiv (2014 - 09 - 04) [2025 - 12 - 10]. https://doi.org/10.48550/arXiv.1409.1556.
[21] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR),2018:7132 - 7142.
[22] Torressánchez J, Lópezgranados F, Serrano N, et al. High-Throughput 3-D monitoring of agricultural-tree plantations with unmanned aerial vehicle (UAV) technology[J]. PLoS One, 2015, 10(6): e0130479.
[23] 王金星,刘雪梅,刘双喜,等. 基于组合色彩特征的苹果树叶片各生长期氮含量预测[J]. 农业机械学报,2021,52(10): 272 - 281,376.
Wang Jinxing, Liu Xuemei, Liu Shuangxi, et al. Prediction of nitrogen content in apple leaves in each growth period based on combined color characteristics[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(10):272 - 281, 376. (in Chinese)
[24] He L, Shao F, Ren L. Sustainability appraisal of desired contaminated groundwater remediation strategies: an information-entropy-based stochastic multi-criteria preference model[J]. Environment, Development and Sustainability, 2021, 23(2): 1759 - 1779.
[25] 秦晓东,戴廷波,荆奇,等. 冬小麦叶片氮含量时空分布及其与植株氮营养状况的关系[J]. 作物学报,2006,32(11): 1717 - 1722.
Qin Xiaodong, Dai Tingbo, Jing Qi, et al. Temporal and spatial distribution of leaf nitrogen content and its relationship with plant nitrogen status in winter wheat[J]. Acta Agronomica Sinica, 2006,32(11):1717 - 1722. (in Chinese)
[26] Osco L P, Junior J M, Ramos A P M, et al. Leaf nitrogen concentration and plant height prediction for maize using UAV-based multispectral imagery and machine learning techniques[J]. Remote Sensing, 2020, 12(19): 3237.
[27] Almalki F A, Soufiene B O, Alsamhi S H, et al. A low-cost platform for environmental smart farming monitoring system based on IoT and UAVs[J]. Sustainability, 2021, 13(11): 5908.
[28] Ziesche P, Gunnarsson O, John W, et al. Two-site hubbard model, the bardeen-cooper-schrieffer model, and the concept of correlation entropy[J]. Physical Review B, 1997, 55(16): 10270.
[29] Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16: 321 - 357.
[30] Kou J, Duan L, Yin C, et al. Predicting leaf nitrogen content in cotton with UAV RGB images[J]. Sustainability, 2022, 14(15): 9259.
[31] Qiu Z, Ma F, Li Z, et al. Estimation of nitrogen nutrition index in rice from UAV RGB images coupled with machine learning algorithms[J]. Computers and Electronics in Agriculture, 2021, 189: 106421.
[32] Ge H, Xiang H, Ma F, et al. Estimating plant nitrogen concentration of rice through fusing vegetation indices and color moments derived from UAV - RGB images[J]. Remote Sensing, 2021, 13(9): 1620.
[33] 宋晓,许端阳,黄绍敏,等. 基于地面观测光谱数据的冬小麦冠层叶片氮含量反演模型[J]. 应用生态学报,2020,31(5): 1636 - 1644.
Song Xiao, Xu Duanyang, Huang Shaomin, et al. Nitrogen content inversion of wheat canopy leaf based on ground spectral reflectance data[J]. Chinese Journal of Applied Ecology, 2020,31(5):1636 - 1644. (in Chinese)
[34] Ulrich A. Physiological bases for assessing the nutritional requirements of plants[J]. Annual Review of Plant Physiology, 1952, 3(1):207 - 228.